



Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Günlük Ortalama Akımların Yapay Sinir Ağları Metodu ile Taşkın Öteleme Hesabında Kullanılması

 Metin SARIGÖL^{a*}

^a Üzümlü Meslek Yüksekokulu, Erzincan Binali Yıldırım Üniversitesi, Üzümlü, Erzincan, TÜRKİYE

* Sorumlu yazarın e-posta adresi: metinsarigol@hotmail.com

DOI: 10.29130/dubited.877756

ÖZ

Bu çalışmada, Büyük Menderes Havzası'ndaki Menderes Nehri üzerinde yer alan E07A043 Ertuğrul ve D07A115 Yenice Regülatör Girişi Akım Gözlem İstasyonlarına (AGİ) ait günlük ortalama hidrograf verileri kullanılmıştır. Bu veriler Yapay Sinir Ağları Metodu kullanılarak eğitim ve test aşamalarından geçirilmiş, kurulan bu modele 2015 yılındaki taşkın verileri uygulanarak Taşkın Öteleme hesapları yapılmıştır. Elde edilen sonuçlar, hem ölçülmüş değerlerle hem de Yapay Sinir Ağları Metodu sonuçları ile karşılaştırılmıştır. Karşılaştırma analizinde Belirlilik Katsayısı (R^2), Hataların Ortalama Karekökü (HOK) değerleri hesaplanmıştır. Sonuçta, günlük akım verilerinin uygulandığı Yapay Sinir Ağları Metodu ile yapılan tahmin sonuçlarının oldukça iyi sonuçlar verdiği, bir sonraki yıla ait taşkın öteleme sonuçlarının ise iyi sayılabilecek bir düzeyde olduğu tespit edilmiştir.

Anahtar Kelimeler: Taşkın ötelenmesi, Yapay sinir ağları, Taşkın, Büyük Menderes

Use of Daily Average Flows in Flood Routing Calculation with Artificial Neural Network Method

ABSTRACT

In this study, daily mean hydrograph data of E07A043 Ertuğrul and D07A115 Yenice Regulator Girişi Stream Gauging Stations (SGS) located on Menderes River in Buyuk Menderes Basin were used. These data were passed through the training and testing stages using the Artificial Neural Networks Method, Flood Routing calculations were made by applying the flood data of 2015 to this model. The results were compared with both Artificial Neural Networks Method and the measured values results. At the end of comparative analysis, Root Mean Square Errors (RMSE) and Coefficient of Determination (R^2) values were calculated. In conclusion, it has been determined that the results of the predictions performed by Artificial Neural Networks Method, where the daily mean hydrograph data is applied, yielded very good results, and the flood routing results for the next year are at a level that can be considered good.

Keywords: Flood routing, Artificial neural network, Flood, Büyük Menderes

I. GİRİŞ

Nedeni ne olursa olsun herhangi bir akarsudaki su seviyesi normalden yüksek olduğunda, doğal kıyıları aştığında ve çevredeki arazileri kapladığında taşkın olarak kabul edilir. Taşkınlar, dünyaya çok fazla zarar veren en önemli doğa olaylarından biridir ve ülkeler her yıl çok fazla maliyet öderler [1]. Yağış, toprak geçirgenliği ve arazi eğimi gibi faktörler, yağışların belirli bir dönemde taşkın oluşumuna neden olması nedeniyle anahtar rol oynarlar [2]. Fırtına taşkınları da sık sık meydana gelir ve kurak dağlık alanlarda karmaşık özelliklere sahiptir; bu da uzun süredir taşkın tahminlerinde zayıf bir halka oluşturmuştur [3]. Taşkınlar meydana geldikten sonra, doğrudan etkiler arasındaki zayıflar, tarımsal üretim kaybı, altyapının zarar görmesi [4], ticaret ve eğitimin bozulması, dolaylı olarak topluluklar üzerindeki sosyal etkiler [5] ve insan sağlığı yer alır [6],[7]. Özellikle yağış miktarının yüksek olduğu kurak dağlık alanlarda, çok kuru ve kabuklu toprak yapısı, yağışları hızla akışa dönüştürebilir ve bu da daha yüksek taşkın riskleri ve yıkıcılığa neden olabilir [8],[9]. Aynı zamanda, bu bölgelerdeki ani taşkınlar, heyelanlar ve enkaz akışları gibi bir dizi jeolojik felaketin eşlik etmesi muhtemeldir [10]. Doğru taşkın tahmini, taşkın kayıplarını azaltmak için yapılan taşkın uyarısının, taşkın kontrolünün ve diğer taşkın şiddetini hafifletme önlemlerinin erken benimsenmesini etkin bir şekilde destekleyebilir [11],[12].

Taşkın Ötelenmesi, bir taşkın dalgasının akarsu ya da hazne boyunca, belirlenen herhangi bir konumdaki debi, hız vb. gibi değerlerin zamanla değişiminin hesaplanmasıdır. Bu durum, taşkınların tahmini ve taşkınının meydana geldiği bölgede, gerekli olan tüm önlemlerin alınmasında büyük önem arz etmektedir. Akarsular üzerinde yapılacak farklı yapılar için akım seviyesi, hızı ve debisi gibi taşkına ait karakteristiklerin bilinmesi ve bunlara göre önlemlerin alınması gerekmektedir [13]. Taşkın öteleme, taşkın kontrolü için en önemli mühendislik tekniklerinden biridir [14], [15], [16].

Günümüzde araştırmacılar, karmaşık sorunları analiz etme becerilerinin yüksek olması nedeniyle çoğunlukla yapay zeka yöntemlerini tercih etmektedir. Yapay sinir ağı (YSA) gibi hesaplamalı zeka tekniklerinin, verilerden 'öğrenme' yeteneğine sahip oldukları için karmaşık ve doğrusal olmayan sistemleri simüle edebildikleri birçok alanda kanıtlanmıştır. Bu yöntemler, gözlemlenen verilerle girdi ve çıktı arasında mantıksal bir bağlantı oluşturabilir. YSA, su kaynakları da dahil olmak üzere birçok alanda başarıyla uygulanmıştır. YSA tabanlı yazılımsal hesaplama modelleri, tüm avantajlarına rağmen kara kutu modelleridir. Bu modeller, anlaşılması zor olan bazı önkoşullara sahip ağırlık matrisleridir [17]. YSA'nın eksik verilerle başa çıkma ve gerçek zamanlı olarak tahmin edilmekte olan olaydan "öğrenme" yeteneği, onu geleneksel toplu veya yarı dağıtılmış taşkın tahmin modellerine çekici bir alternatif haline getirir [18]. Gelecekteki araştırma çabaları, YSA modellerinin geliştirilmesine yardımcı olan kılavuzların geliştirilmesine ve YSA'ların alternatif yaklaşımlar yerine ne zaman kullanılması gerektiğinin seçimine, bağlantı ağırlıklarında yer alan bilgiyi çıkarma yöntemlerinin değerlendirilmesine yönelik olmalıdır [19]. YSA modelleri ortalama aylık nehir akımını tahmin etmede, Hint nehir havzasının yağış-akış modellemesi için geliştirilmiş farklı tipte yapay sinir ağı modellerinin performansının kapsamlı bir değerlendirmesinde kullanılmıştır [20], [21]. Kuzey-Batı Arkansas ve Kuzey-Doğu Oklahoma'da bulunan bir tarımsal havza olan Eucha Watershed'deki çoklu ölçüm istasyonlarında günlük akımları tahmin etmek için YSA modelleri, hidrolojik sonuçları tahmin etmek için faydalı araçlar olduğunu göstermektedir [22]. İran'ın Fars eyaletinin kuzeybatı kesiminde yer alan Hüsrev Şirin havzasından günlük akımları tahmin etmek için yapay sinir ağı modellerinin kullanımı tartışılmıştır [23]. Günlük kesintili akımları tahmin etmek için de YSA modellerinden faydalanılmıştır [24].

Yapay sinir ağı metodu kullanılarak, çoklu girişler göz önünde bulundurulup, mansaptaki taşkını belirlemiştir [25]. Yapay sinir ağı tabanlı yağış akışı modelinde ağ yapısını tasarlamak için yeni bir yaklaşım sunulmuş, sonuçların ise bir YSA modeli geliştirmek için gereken çabayı ve hesaplama süresini önemli ölçüde azaltabileceği gösterilmiştir [26]. Debi ve tortuyu tahmin etmek ayrıca debi ve su seviye tahmininde YSA modelinden faydalanılmıştır [27], [28]. YSA ve destek vektör makinesi (SVM) modelleri kullanılarak Zayandehroud baraj rezervuarına girişi tahmin etmek için farklı yeni

girdi modelleri önerilmiştir [29]. Bir Coğrafi Bilgi Sistemi ortamında çok kriterli analiz ve YSA tekniklerini kullanarak ulusal ölçekte bir taşkın tehlikesi değerlendirme metodolojisi tanıtılmış, bu şekilde Yunanistan için genel taşkın tehlike haritası belirlenmiştir [30].

YSA'lar girdi ve çıktı arasındaki ilişkiyi tanımak için bir sistemin fiziksel olarak karmaşık süreçleri hakkında ayrıntılı bilgi gerektirmez [31]. YSA'da amaç, temsil ettiği olayın karakterini ayrıntılı olarak anlamaya çalışmadan, bir sistem reaksiyon tahminine ulaşmaktır. Karmaşık bir tasarım problemi çözülürken gereken bilgisayar süresi önemli ölçüde kısalmaktadır ve sonuçta zamandan önemli ölçüde tasarruf sağlanır [32], [33].

Günlük ortalama akım verileri ile YSA'da oluşturulan modelin, ani akım verilerine uygulanarak taşkın ötelemesi hesabında kullanılmasıyla literatürde ilk olarak yapılan bu çalışma, karmaşık bir nehir ağındaki akış problemlerine YSA uygulamasını içermektedir. Amaç, bir nehir boyunca akım tahmini için bir YSA kanal ağ modeli oluşturmak ve ayrıca YSA yönteminin verimliliğini ve etkinliğini ifade etmektir. Model, YSA mimarisi olarak simüle edilen ve nehir sisteminin önemli performansını ve iç durumunu içeren gerçek nehir ağını kullanır. Modele fiziksel davranışın dahil edilmesi ve YSA oluşturulması için doğal nehir ağının kullanılması, YSA'nın modellenmesi için en uygun mimariye sahip olmayı mümkün kılar ve ayrıca su kaynakları mühendislerinin teknikleri anlamasını ve sonucu çıkarmasını kolaylaştırır. YSA modellemesi, bir hidrodinamik modele kıyasla topoğrafya bilgisi için gerekli olan daha az sayıda veriye sahip karmaşık bir nehir sistemindeki akımın gerçek zamanlı tahmini için önerilmiştir.

Bu çalışma ile varılmak istenen en önemli amaç, günlük ortalama hidrograf verilerinin YSA ile bir modelin kurulması ve kurulan modeller yardımıyla ileriye yönelik taşkın tahminlerinin yapılması olanağının araştırılmasıdır. Günlük ortalama akım verilerine ulaşmanın kolay olması ve akım gözlem istasyonların çoğunda bu verilerin bulunması sebebiyle, sonuçta yapılacak modellemelerin tüm bölgelere kolaylıkla uygulanabileceği umulmaktadır.

Araştırmada, ilk aşaması bir akarsuda mevcut günlük ortalama akım verileri kullanılarak YSA metodunda eğitim ve test aşamalarından geçirilip bir modelin kurulmasıdır. Sonraki aşamada ise, bir sonraki yıla ait taşkın verilerinin kurulan bu modele uygulanarak taşkın öteleme tahmininin yapılmasıdır. Bu şekilde, başka hiçbir veriye ihtiyaç duymadan YSA metoduyla kurulan bu modele, sadece giriş verileri eklenerek, ileride meydana gelebilecek bir taşkınım önceden tahmin edilmesine olanak sağlayacağı düşünülmektedir. Ayrıca öteleme işlemleri hesaplanırken sürtünme katsayısı, eğim gibi parametrelerin de hesap edilmesine gerek kalmaması, modellerin kolay ve kısa zamanda oluşturulması, zaman tasarrufu açısından da önemli bir yer tutacağı aşıkardır.


Sonuçta bu bölgenin kilometrelerce uzağındaki mansap bölgesinde, ileriki zamanlarda meydana gelebilecek taşkın hidrografının, saatlerce bazen de günlerce önceden tahmin edilmesi mümkün olmaktadır. Böylece can ve malın korunması, kurtarılması için de gerekli olan sürenin kazanılması, taşkınım sebep olabileceği zararların da en aza indirilmesi amaçlanmaktadır.

II. YÖNTEM

Büyük Menderes Nehri'nde 01.10.2012-31.01.2015 tarihleri arasındaki 853 adet günlük ortalama debi verileri YSA Metodu ile modellenmiş, eğitim ve test aşamalarından geçirilmiştir. Oluşturulan bu modellere 02.02.2015 tarihli 93 adet taşkın verileri uygulanarak taşkın öteleme sonuçları tahmin edilmiştir. Elde edilen sonuçlar ölçülen değerler ile karşılaştırılmış, hata analizleri yapılmıştır. YSA modellemeleri MATLAB programı ile gerçekleştirilmiş ve grafikleri çizilmiştir.

2. 1. Yapay Sinir Ağları

YSA'lar, nöronlardan oluşan bir işlemcidir. Eğitim süreci boyunca bilgi öğrenebilir ve depolayabilir. YSA'lar doğrusal olmama durumunun üstesinden gelebilir ve bu nedenle hidrolojide taşkın hidrograf tahmini de dahil olmak üzere birçok disiplinde geniş bir uygulamaya sahiptir. Genel olarak, Şekil 1'de gösterildiği gibi üç katmanlı ağ, taşkın hidrograf tahmin problemlerinde kavramsallaştırılır. Böyle bir ağda (Şekil 1); giriş değerleri (x_i) ilk olarak giriş katmanı nöronlarına girilir. Bağlantı ağırlıkları (v_{ij}) ile çarpılır ve ardından gizli katman nöronlarına aktarılır. Her nöron, alınan tüm ağırlıklı bilgileri ($x_i v_{ij}$) toplar ve ardından toplamı bir aktivasyon fonksiyonundan geçirerek bir çıktı (z_i) üretir ve bu da çıktı katmanı nöronu için giriş sinyali olur. Her bir iç katman nöronundan gelen çıktı, ilgili bağlantı ağırlığı (w_{ij}) ile çarpılır ve daha sonra, alınan tüm sinyali ($z_i w_{ij}$) toplayan ve ağ çıkışını (y_i) üretmek için bir aktivasyon fonksiyonundan geçiren çıkış nöronuna aktarılır.



Şekil 1. Üç katmanlı bir YSA ağı.

Bağlantı ağırlıklarının optimal değerleri, gradyan azaltma yöntemi kullanılarak hata fonksiyonunu en aza indiren geri yayılma algoritması ile bulunabilir. En aza indirgenmiş hata fonksiyonu E , aşağıdaki Denklem (1) ile ifade edilir:

$$E = \sum_1^p (t_i - y_i)^2 \quad (1)$$

y_i : ağ çıkışı, t_i kullanıcı tanımlı hedef çıktı ve p eğitim verilerinin sayısıdır. Bağlantı ağırlıkları (w_{ij}) aşağıdaki gibi Denklem (2) kullanılarak her iterasyonda güncellenir:

$$\Delta w_{ij}(n) = \alpha \Delta w_{ij}(n-1) - \delta \frac{\partial E}{\partial w_{ij}} \quad (2)$$

burada $\Delta w_{ij}(n) = w_{ij}^{\text{old}} - w_{ij}^{\text{new}}$, şimdiki iterasyon (n), ve $\Delta w_{ij}(n-1) = w_{ij}^{\text{old}} - w_{ij}^{\text{new}}$, önceki iterasyondur ($n-1$). δ : öğrenme hızı ve α : momentum faktörüdür ve 0 ile 1 arasında değerler alınır. Aktivasyon fonksiyonu olarak tanjant hiperbolik (\tanh) kullanıldığında;

$$f(\text{toplama}) = \frac{2}{1 + e^{-2\text{toplama}}} - 1 \quad (3)$$

denklemindeki toplam, nöron tarafından alınan toplam bilgidir. Tanjant hiperbolik fonksiyon -1 ile +1 arasında sınırlandırılmıştır ve bu nedenle tüm değerler Denklem (4) tarafından -0.9 ve +0.9'a sıkıştırılmıştır.

$$z_i = \left[\frac{1.8(x_i - x_{\min})}{x_{\max} - x_{\min}} \right] - 0.9 \quad (4)$$

burada z_i standartlaştırılmış değerdir, x_{\min} kümedeki minimum değerdir; ve x_{\max} kümedeki maksimum değerdir [34].

2. 2. Öteleme Başarısının Sınanması

Modelin başarısını ölçmek için çok sık kullanılan metot Hataların Ortalama Karekökü (HOK) dır. HOK (Hataların Ortalama Karekökü) hesaplanan değer ile gerçek değer arasındaki farkın standart sapmasıdır. Bu fark, regresyon çizgisinden veri noktalarından ne kadar uzak olduğunun bir ölçütüdür [35].

$$HOK = \sqrt{\frac{\sum_{i=1}^n (Q_{i_{hesap}} - Q_{i_{gercek}})^2}{n}} \quad (5)$$

Burada; $Q_{i_{hesap}}$: Hesaplanan debi, $Q_{i_{gözlünen}}$: Ölçülen debi, n : Veri sayısı olarak tanımlanır.


Yine modelin başarısını ölçmede kullanılan ikinci metot R^2 (Belirlilik) katsayısı, hesaplanan değer ile gerçek değer arasındaki lineer regresyonu diğer bir ifade ile uyumu temsil eder ve aşağıda yer alan formülle ifade edilir. Eğilim analizinde ağırlık kazanır ve 0 ile 1 arasında bir değer olarak temsil edilir. Sonuç değer 1'e kadar yaklaşırsa, iki faktör arasındaki uyum ya da ilişki o kadar iyi olur [36].

$$R^2 = \left(\frac{\sum_{i=1}^n (Q_{i_{gercek}} - Q_{ort_{gercek}})(Q_{i_{hesap}} - Q_{ort_{hesap}})}{\sqrt{\sum_{i=1}^n (Q_{i_{gercek}} - Q_{ort_{gercek}})^2 \sum_{i=1}^n (Q_{i_{hesap}} - Q_{ort_{hesap}})^2}} \right)^2 \quad (6)$$

Burada; $Q_{i_{hesap}}$: Hesaplanan debi, $Q_{ort_{hesap}}$: Hesaplanan Debi Ortalaması, $Q_{i_{gercek}}$: Ölçülen Debi, $Q_{ort_{gercek}}$: Hesaplanan Debi Ortalaması, n : Veri sayısı

2. 3. Çalışmada Kullanılan Veriler

Çalışmada 38:4:44 Kuzey, 29:0:19 Doğu koordinatlarında, 176 m rakımdaki E07A043 nolu Ertuğrul AGİ giriş verileri olarak ve 38:3:7 Kuzey, 28:58:11 Doğu koordinatlarında, 160 m rakımda yer alan D07A115 nolu Yenice Regülatör Girişi AGİ çıkış verisi olarak istasyonlarının günlük ortalama akım verileri kullanılmıştır (Şekil 2).



Şekil 2. E07A043 ve D07A115 AGİ'lere ait günlük hidrograf.

Çalışma verilerinin elde edildiği Akım Gözlem İstasyonlarının özellikleri ve parametreleri Tablo 1'de yer almaktadır.

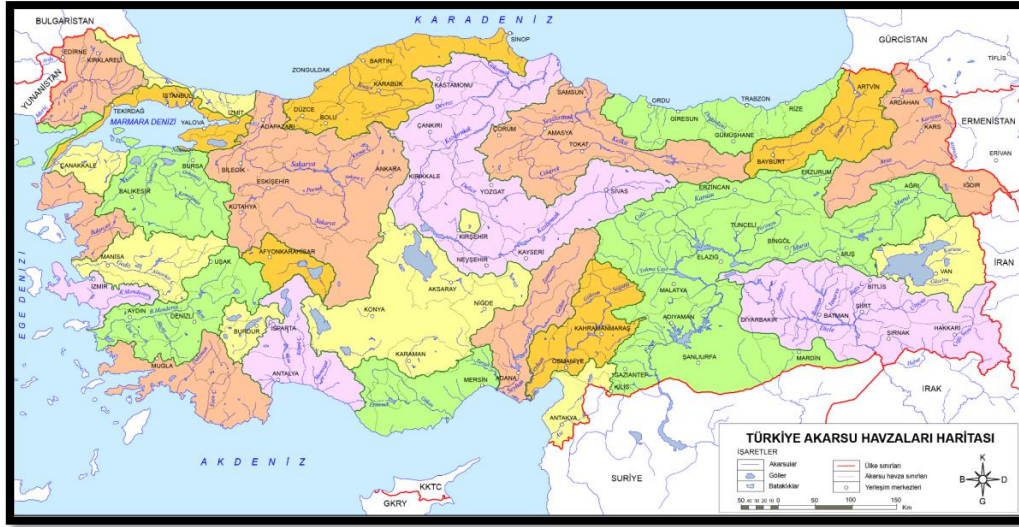
Tablo 1. AGİ'lerin özelliği.

İl/İlçe Adı	İstasyon No	İstasyonun Kodu	İstasyon Adı	Havza Adı	Akarsu Adı	İstasyon Kotu (m)	Alan (km ²)
Denizli (Buldan)	1	E07A043	Ertuğrul	Büyük Menderes	Büyük Menderes	176	9731
	2	D07A115	Yenice Regülatör Girişi	Büyük Menderes	Büyük Menderes	160	9452,53


Çalışma verileri, Devlet Su İşleri Genel Müdürlüğü Rasatlar Şube Müdürlüğünden ve DSİ Bölge Müdürlüklerinden elde edilmiştir [37].

2. 4. Çalışma Bölgesi

Taşkın ötelemesi yapılacak olan Büyük Menderes Nehri üzerinde bulunan Akım Gözlem İstasyonları Denizli Buldan, Büyük Menderes Havzası'nda yer almaktadır. Akarsu Havzalarının konumu, çalışma alanı olan Büyük Menderes Havzası ve AGİ'lerin bulunduğu konumlar Şekil 3-4'de gösterilmiştir.



Şekil 3. Türkiye akarsu havzaları haritası [38].



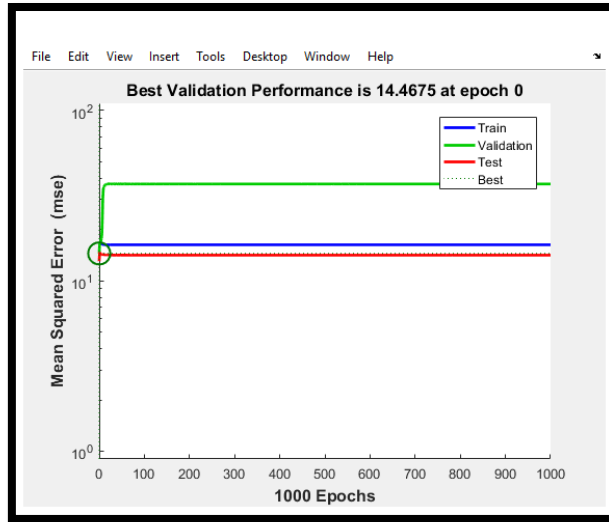
Şekil 4. Büyük Menderes havzası ve E07A043 ve D07A115 AGİ'lerin konumu [39].

III. BULGULAR ve DEĞERLENDİRME

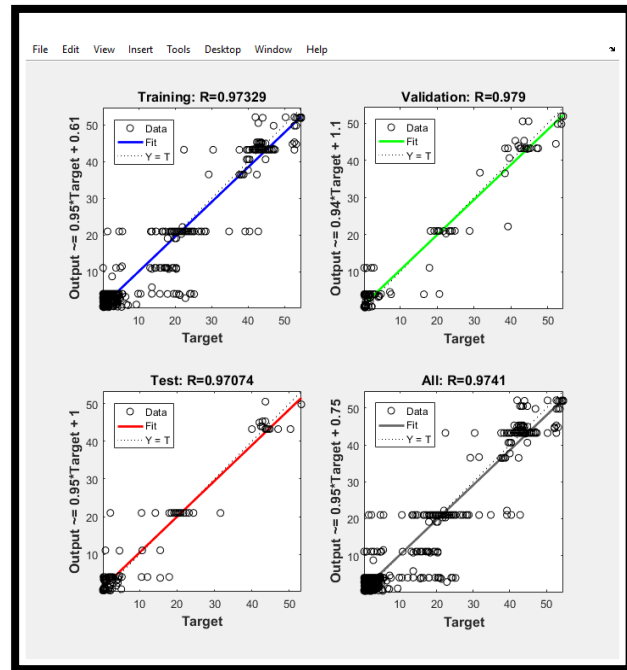
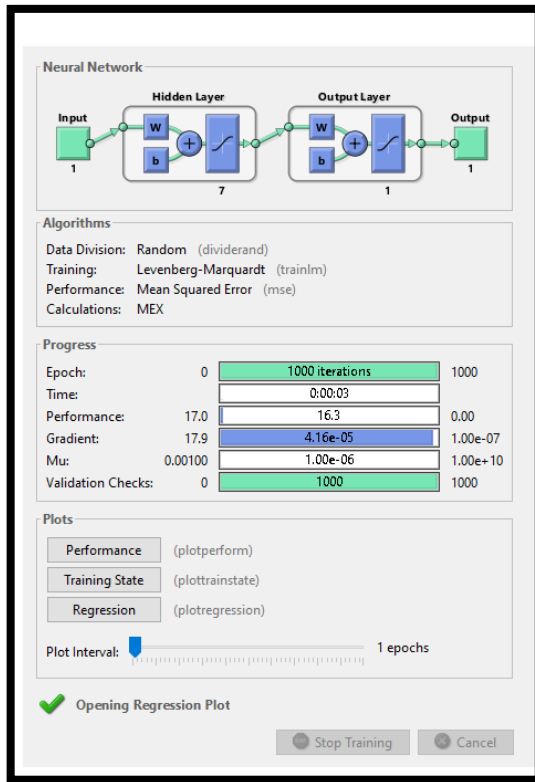
3.1. YSA Eğitim ve Test Taşkın Ötelenme Bulguları

YSA modellemesinde, 853 adet günlük ortalama debi verilerinin ilk %60' lık kısmı eğitim, %40 lık kalan kısmı ise test olarak gerçekleştirilmiştir. Modelin girdi verileri 01.10.2012-31.01.2015 tarihleri arasındaki günlük ortalama akıma ait E07A043 nolu Ertuğrul AGİ verileri, çıktı değerleri ise D07A115 nolu Yenice Regülatör Girişi AGİ verileri olarak seçilmiştir. Yapay sinir ağlarında öğrenme fonksiyonu olarak Levenberg-Marquardt kullanılmıştır. Gizli nöron sayısı, literatürde yaygın olarak kullanıldığından dolayı, 3 ile 8 arasında sayıları arasında değiştirilerek hesap yapılmıştır. Modellerin aktivasyon fonksiyonu, Tanjant Sigmoid ve Logaritmik Sigmoid alınarak farklı nöron sayıları için, ileri beslemeli geri yayılım YSA modeli kullanılmıştır.

Genel olarak değerlendirildiğinde aktivasyon fonksiyonu Tanjant Sigmoid olan 7 nöronlu model en başarılı model olmuştur. Bunlar ile ilgili Matlab program çıktı grafikleri Şekil 5-6-7-8' de gösterilmiştir.




Şekil 5. Tanjant Sigmoid 7 nöronlu YSA performans grafiği.

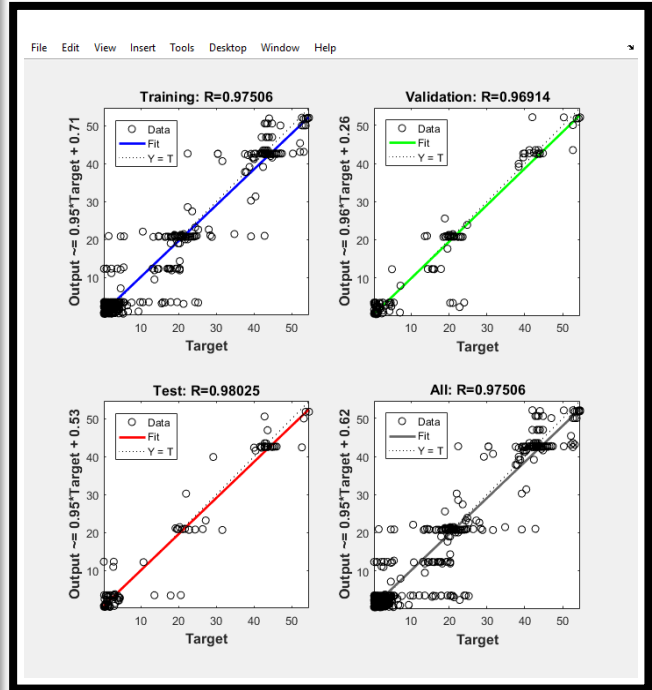
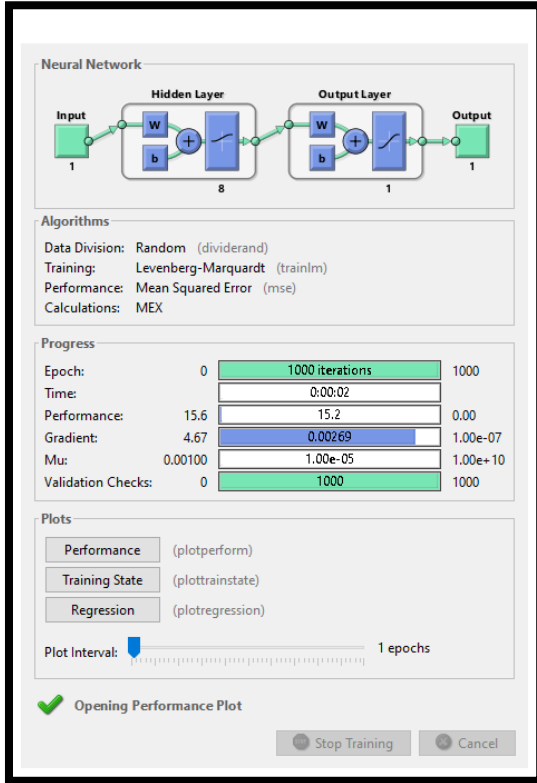


Şekil 6. Tanjant Sigmoid 7 nöronlu YSA mimarisi ve regresyon grafiği.

Şekil 5’de aktivasyon fonksiyonu Tanjant Sigmoid olan 7 nöronlu modelin, iterasyon sayısına bağlı hatanın en az olduğu performans grafiği görülmektedir. Şekil 6’da ise model eğitilirken kullanılan fonksiyonu ve iterasyon sayısına bağlı performans değerleri verilmektedir. Şekil 6’nın grafik kısmında ise YSA ile kurulan modelin eğitim ve test sonuçları görülmekte, eğitim ve test sonuçlarının yaklaşık olarak R=0,97 (Regresyon) olmak üzere yüksek bir oranda eğitim ve test sonuçlarının elde edildiği görülmektedir.

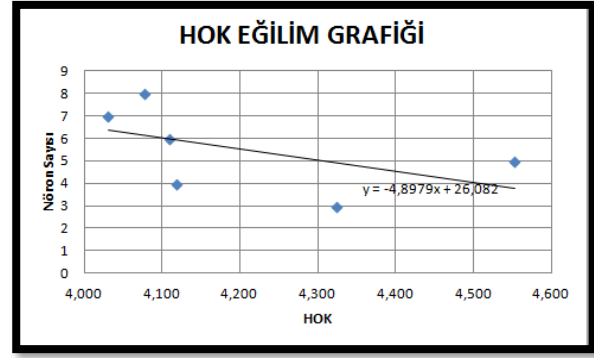



Şekil 7. Logaritmik Sigmoid 8 nöronlu YSA performans grafiği.




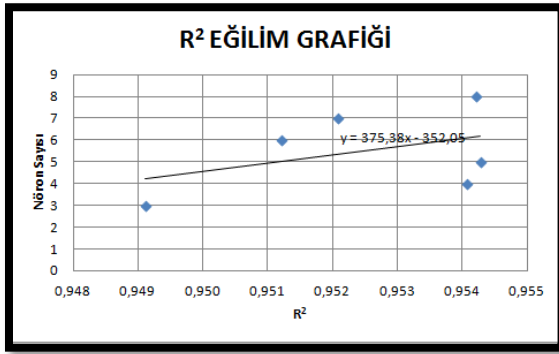
Şekil 8. Logaritmik Sigmoid 8 nöronlu YSA mimarisi ve regresyon grafiği.

Şekil 7’de ise aktivasyon fonksiyonu Logaritmik Sigmoid olan 8 nöronlu modelin, iterasyon sayısına bağlı hatanın en az olduğu performans grafiği görülmektedir. Şekil 8’de ise model eğitilirken kullanılan fonksiyon ve iterasyon sayısına bağlı performans değerleri verilmektedir. Şekil 6’nın grafik kısmında ise YSA ile kurulan modelin eğitim ve test sonuçları görülmekte, yaklaşık olarak $R=0,97$ eğitim, $R=0,98$ (Regresyon) test sonuçları olmak üzere yüksek bir oranda eğitim ve test sonuçlarının elde edildiği görülmektedir.



Şekil 9. Tanjant Sigmoid fonksiyonlu R² ve HOK eğilim.

Tablo 2 incelendiğinde nöron sayısına bağlı olarak Tanjant Sigmoid fonksiyonun test sonuçları olan HOK ve R² değerleri Şekil 9'da gösterilmiştir. Grafikler incelendiğinde, her iki aktivasyon fonksiyonu için gizli nöron sayıları arttığında, HOK değerlerinin azalma eğiliminde, R² değerinin ise artma eğiliminde olduğu ve daha iyi sonuçlar verdiği görülmektedir.



Şekil 10. Logaritmik Sigmoid fonksiyonlu R² ve HOK eğilim grafikleri.

Yine Tablo 2'ye göre nöron sayısına bağlı olarak Logaritmik Sigmoid fonksiyonun test sonuçları olan HOK ve R² değerleri Şekil 10'da gösterilmiştir. Grafikler incelendiğinde, her iki aktivasyon fonksiyonu için gizli nöron sayıları arttığında, HOK değerlerinin azalma eğiliminde, R² değerinin ise artma eğiliminde olduğu ve daha iyi sonuçlar verdiği görülmektedir.

Tablo 2. YSA 01.10.2012-31.01.2015 yılları sonuç hata analizi.

Modeller	Aktivasyon Fonksiyonu	Nöron Sayısı	Eğitim		Test	
			HOK	R ²	HOK	R ²
Model 1	Tanjant Sigmoid	3	4,174	0,939	4,324	0,949
Model 2		4	4,108	0,941	4,119	0,953
Model 3		5	4,202	0,942	4,553	0,951
Model 4		6	3,953	0,945	4,110	0,954
Model 5		7	3,985	0,945	4,031	0,956
Model 6		8	3,923	0,946	4,077	0,954
Model 7	Logaritmik Sigmoid	3	4,169	0,940	4,313	0,949
Model 8		4	4,171	0,940	4,156	0,954
Model 9		5	4,105	0,941	4,072	0,954
Model 10		6	4,002	0,944	4,240	0,951
Model 11		7	4,055	0,943	4,175	0,952
Model 12		8	3,828	0,949	4,080	0,954

Yapılan HOK ve R^2 hata analiz hesaplamalarında, Aktivasyon fonksiyonu Tanjant Sigmoid olan 7 nöronlu YSA ile yapılan model, aktivasyon fonksiyonu Logaritmik Sigmoid olan 8 nöronlu model kendi gruplarında başarılı olmuştur ve Tablo 2’de gösterilmiştir.

Modeller genel olarak değerlendirildiğinde aktivasyon fonksiyonu Tanjant Sigmoid olan 7 nöronlu model en başarılı model olmuştur.

YSA da kurulan bu Model1-Model10 modelleri, programdaki Simulate eklentisi sayesinde, 2015 yılı taşkın verilerine uygulanmıştır. Hesaplanan değerlerle gerçek değerler arasındaki HOK Hata ve R^2 değerleri Tablo 3’de gösterilmiştir.

Tablo 3. YSA 2015 yılı taşkın tahmin sonuç hata analizi.


Modeller	Aktivasyon Fonksiyonu	Nöron Sayısı	2015 yılı Taşkın Tahmini	
			HOK	R^2
Tahmin 1	Tanjant Sigmoid	3	4,117	0,731
Tahmin 2		4	3,853	0,761
Tahmin 3		5	5,521	0,732
Tahmin 4		6	5,972	0,694
Tahmin 5		7	6,633	0,715
Tahmin 6		8	3,901	0,789
Tahmin 7	Logaritmik Sigmoid	3	4,091	0,733
Tahmin 8		4	3,808	0,770
Tahmin 9		5	3,821	0,766
Tahmin 10		6	4,040	0,748
Tahmin 11		7	7,765	0,631
Tahmin 12		8	5,927	0,705

Tablo 3 incelendiğinde YSA ile 01.10.2012-31.01.2015 yılları arasındaki veriler için oluşturulan modellere, 2015 yılı taşkın verileri uygulanmış, Yapılan HOK ve R^2 hata analiz hesaplamalarında, aktivasyon fonksiyonu Tanjant Sigmoid olan 8 nöronlu YSA ile yapılan model, aktivasyon fonksiyonu Logaritmik Sigmoid olan 4 nöronlu model kendi gruplarında başarılı olmuştur.

Tahmin modelleri genel olarak değerlendirildiğinde aktivasyon fonksiyonu Tanjant Sigmoid olan 8 nöronlu model R^2 baz alındığında en başarılı model olmuştur.

3.2. YSA 2015 Yılı Ani Taşkın Ötelenme Bulguları

YSA modeline 2015 yılı taşkın verileri uygulandığında, ölçülen ve öteleme sonuç grafikleri Şekil 11’de gösterilmiştir.



Şekil 11. YSA ve öteleme grafikleri.

Grafikteki giriş ve çıkış verileri belirlenirken, memba tarafında yer alan E07A043 nolu Ertuğrul AGİ için 02.02.2015 tarihli 93 adet ani taşkın debisi giriş verileri, yine aynı tarihli veriler D07A115 nolu Yenice Regülatör Girişi AGİ için ise çıkış verileri olarak ele alınmıştır. Model tahmin değerleri de bu çıkış değerleriyle karşılaştırılarak hata analizleri yapılmıştır.

Tahmin sonuçları için yapılan RMSE ve R^2 karşılaştırmalı analizlerde, YSA'nın $RMSE=3,901$, $R^2 = 0,789$ olarak hesaplanmıştır. Böylece YSA sonuçlarının, başka hiç bir veriye ihtiyaç duymadan iyi sayılabilecek bir tahmin yapabildiği görülmüştür.

IV. SONUC

Bu çalışmada 01.10.2012-31.01.2015 yılları arasındaki günlük ortalama akım verileri kullanılarak, ileriye dönük taşkın öteleme hesabı yapılmıştır. Son yıllarda, birçok bilimsel alanda oldukça fazla kullanılan YSA metodu, hidrolojik olaylardan taşkın verilerine uygulanabilirliği araştırılmıştır. Taşkın verilerinde içsel bağımlılığın çok kuvvetli olması sebebiyle anlık taşkın hidrograf verileri kullanılarak yapılan YSA modellerin tamamında $R^2=0,95$ 'ye yakın çok iyi test tahmin değerleri bulunmuştur.

02.02.2015 yılında meydana gelen taşkın için, o yıla ait başka hiç bir parametre kullanmadan, sadece menba verileri girilerek, mansab bölgesi için yapılan tahminlerde ise, $R^2=0,63-0,79$ arasında iyi sayılabilecek bir tahmin başarısı göstermiştir.

Stokastik modellerde, model oluşturulmadan önce kontrol edilmesi gereken normal dağılım, durağanlık, sabit varyans gibi koşullar, taşkın öteleme metodlarının bir kısmında ise sınır şartlarının belirlenmesi gibi yapılması gereken birçok işlem vardır. Bu işlemler araştırma yapanların fazlaca efor ve zaman kaybetmesine sebep olmaktadır. Bu çalışmada kullanılan YSA'da herhangi sınır şartı vb. bir işlem yapmadan bir çok fiziksel olayın modellenmesine basitçe uygulanabilmektedir. Taşkın ile ilgili araştırma yapanlar için, bu tür yöntemlerin kullanılması ve farklı algoritmaların da eklenmesiyle çok az veri kullanılarak, ileriye yönelik tahmin olanaklarının geliştirilebileceği ve sıklıkla kullanılabilceği öngörülmektedir.

Sonuç olarak, başka hiçbir veriye ihtiyaç duymadan mevcut yıldaki günlük akım verileri ile YSA'da kurulan bu modele, sonraki yılın sadece taşkın giriş verileri eklenerek, mansap bölgesinde meydana gelebilecek bir taşkın önceden tahmin edilmesine kolaylıkla olanak sağlayacağı düşünülmektedir. Ayrıca farklı istasyonlar için de YSA ile kurulacak modellerin, farklı mansap bölgelerinde taşkın öteleme hesaplarında büyük kolaylık sağlayabileceği, buna bağlı olarak önceden tedbir almanın hayati önem arz edeceği umulmaktadır.

V. KAYNAKLAR

- [1] M. R. Hassanvand, H. Karami, and S. F. Mousavi, "Investigation of neural network and fuzzy inference neural network and their optimization using meta-algorithms in river flood routing," *Natural Hazards*, vol. 94, pp. 1057–1080, 2018.
- [2] P. K. T. Nguyen and L. H. C. Chua, "The data-driven approach as an operational real-time flood forecasting model," *Hydrol Process*, vol. 26, pp. 2878–2893, 2012.
- [3] X. Yuan, X. Zhang and F. Tian, "Research and application of an intelligent networking model for flood forecasting in the arid mountainous basins," *J Flood Risk Management*, vol. 13, pp. e12638, 2020.
- [4] R. Pant, S. Thacker, J. W. Hall, D. Alderson and S. Barr, "Critical infrastructure impact assessment due to flood exposure," *Journal of Flood Risk Management*, vol.11, no. 1, pp. 22–33, 2018.
- [5] M. K. Lindell and C. S. Prater, "Assessing community impacts of natural disasters," *Natural Hazards Review*, vol. 4, no. 4, pp. 176–185, 2003.
- [6] W. Du, G. J. FitzGerald, M. Clark and X. Hou, "Health impacts of floods," *Prehospital and Disaster Medicine*, vol. 25, no. 3, pp. 265–272, 2010.
- [7] S. N. Jonkman and J. K. Vrijling, "Loss of life due to floods," *Journal of Flood Risk Management*, vol.1, no. 1, pp. 43–56, 2008.
- [8] Z. W. Kundzewicz, S. Kanae, S. I. Seneviratne, J. Handmer, N. Nicholls, P. Peduzzi and B. Sherstyukov, "Flood risk and climate change: Global and regional perspectives," *Hydrological Sciences Journal*, vol. 59, no. 1, pp. 1–28, 2014.
- [9] Z. Sen, H. A. Khiyami, S. G. Al-Harthy, F. A. Al-Ammawi, A. B. Al-Balkhi, M. I. Al-Zahrani, and H. M. Al-Hawsawy, "Flash flood inundation map preparation for wadis in arid regions," *Arabian Journal of Geosciences*, vol. 6, no. 9, pp. 3563–3572, 2013.
- [10] Tu. T Van, D. M Duc, N. M. Tung and V. D. Cong, "Preliminary assessments of debris flow hazard in relation to geological environment changes in mountainous regions, North Vietnam," *Vietnam Journal of Earth Sciences*, vol. 38, no. 3, pp. 277–286, 2016.
- [11] A. Guven, "Linear genetic programming for time-series modelling of daily flow rate," *Journal of Earth System Science*, vol. 118, no. 2, pp. 137–146, 2009.
- [12] Z. M. Yaseen, A. El-shafie, O. Jaafar, H. A. Afan and K. N. Sayl, "Artificial intelligence based models for stream-flow forecasting: 2000–2015," *Journal of Hydrology*, vol. 530, pp. 829–844, 2015.
- [13] M. Sarıgöl, "Adana İli Karaisalı İlçesi Seyhan Havzası'nda Taşkın Ötelenmesi Yöntemlerinin Karşılaştırılması ve Analizi, Muskingum Yönteminin Sürtünme Katsayısına (n) Bağlı Performans Analizi," *Bartın University International Journal of Natural and Applied Sciences*, vol. 2, no. 2, pp. 129-137, 2019.
- [14] T. A. Birkland, R. J. Burby, D. Conrad, H. Cortner and W. K. Michener, "River ecology and flood hazard mitigation," *Nat Hazards Rev*, vol. 4, no. 1, pp. 46–54, 2003.

- [15] S. D. Brody, S. Zahran, P. Maghelal, H. Grover, and W. E. Highfield, "The rising costs of floods: examining the impact of planning and development decisions on property damage in Florida," *J Am Plan As*, vol. 73, no. 3, pp. 330–345, 2007.
- [16] N. W. Chan, "Impacts of disasters and disasters risk management in Malaysia: the case of floods," In: Sawada Y, Oum S (eds) *Economic and welfare impacts of disasters in East Asia and Policy responses*, ERIA Research Project Report 2011-8, ERIA, Jakarta, pp. 503–551, 2012.
- [17] A. Pashazadeh and M. Javan, "Comparison of the gene expression programming, artificial neural network (ANN), and equivalent Muskingum inflow models in the flood routing of multiple branched rivers," *Theoretical and Applied Climatology*, vol. 139, pp. 1349–1362, 2020.
- [18] C. W. Dawson, and R. Wilby, "An artificial neural network approach to rainfall-runoff modeling," *Hydrol Sci J*, vol. 43, no.1, pp. 47–66, 1998.
- [19] H. R. Maier and G. C. Dandy, "Neural networks for the prediction and forecasting of water resources variables: a review of modeling issues and applications," *Environ Model Softw*, vol. 15, pp. 101–123, 2000.
- [20] O. Kisi, "River flow modeling using artificial neural network," *ASCE J Hydrol Eng*, vol. 9, no. 1, pp. 60–63, 2004.
- [21] A. P. S. Kumar, K. P. Sudheer, S. K. Jain and P. K. Agarwal, "Rainfall-runoff modeling using artificial neural networks: comparison of network types," *Hydrol Process*, vol. 19, pp. 1277–1291, 2005.
- [22] E. Mutlu, , I. Chaubey, H. Hexmoor and S. G. Bajwa, "Comparison of artificial neural network models for hydrologic predictions at multiple gauging stations in an agricultural watershed," *Hydrol Process*, vol. 22, no.26, pp. 5097–5106. 2008.
- [23] M. R. Zadeh, S. Amin, D. Khalili and V. P .Singh, "Daily outflow prediction by multilayer perceptron with logistic sigmoid and tangent sigmoid activation functions," *Water Resour Manag*, vol. 24, no. 11, pp. 2673–2688, 2010.
- [24] O. Kisi, A. M. Nia, M. G. Gosheh, M. R. J Tajabadi and A. Ahmadi, "Intermittent streamflow forecasting by using several data driven techniques," *Water Resour Manage*, vol. 26, no. 2, pp.457–474, 2012.
- [25] B. S. Sil and B. Das, "Determination of downstream flood flow considering inputs from different upstream rivers using ANN," *J Urban Environ. Eng. (JUEE)*, vol. 12, no. 1, 2018.
- [26] K. P. Sudheer, A. K. Gosain and K. S. Ramasastri, "A data-driven algorithm for constructing artificial neural network rainfall–runoff models," *Hydrologic Processes* , vol.16, pp. 1325–1330, 2002.
- [27] B. Bharti, A. Pandey, S. K. Tripathi and D. Kumar, "Modelling of runoff and sediment yield using ANN, LS-SVR, REPTree and M5 models," *Hydrology Research*, vol. 48, no. 6, pp. 1489–1507, 2017.
- [28] F. D. Mwale, A. J. Adeloye and R. Rustum, "Application of selforganising maps and multi-layer perceptron-artificial neural networks for streamflow and water level forecasting in datapoor catchments: the case of the Lower Shire floodplain, Malawi," *Hydrology Research*, vol. 45, no. 6, pp. 838–854, 2014.

- [29] M. Babaei, R. Moeini, and E. Ehsanzadeh, "Artificial neural network and support vector machine models for inflow prediction of dam reservoir case study: Zayandehroud Dam Reservoir," *Water Resources Management*, vol. 33, pp. 2203, 2019.
- [30] N. N. Kourgialas and G. P. Karatzas, "A national scale flood hazard mapping methodology: the case of Greece—Protection and adaptation policy approaches," *Science of the Total Environment*, vol. 601, pp. 441–452, 2017.
- [31] N. Dehghanian, S. S. M. Nadoushani, B. Saghafian and M. R. Damavandi, "Evaluation of coupled ANN-GA model to prioritize flood source areas in ungauged watersheds," *Hydrology Research*, vol. 51, no.3, 2020.
- [32] K. Hornik, "Multilayer feed forward networks are universal approximations," *Neur. Networks*, vol. 2, no.4, pp. 359–366, 1989.
- [33] J. L. Rogers and W. J. Lamarsh, "Application of a neural network to simulate analysis in an optimization process Proceedings, " *Artificial Intelligence in Design 92*, Kluwer Academic, Boston, pp. 739–754, 1992.
- [34] G. Tayfur, V. P. Singh, T. Moramarco and B. Barbetta, "Flood Hydrograph Prediction Using Machine Learning Methods," *Water*, vol. 10, pp. 968, 2018.
- [35] H. K. Demissie and P. Bacopoulos, "Parameter Estimation of Anisotropic Manning's n Coefficient for Advanced Circulation (ADCIRC) Modeling of Estuarine River Currents (lower St. Johns River) , " *Journal of Marine Systems* vol.169, pp. 1–10, 2017.
- [36] M. Zare and M. Koch, "An Analysis of MLR and NLP for Use in River Flood Routing and Comparison with the Muskingum Method," *IAHR World Congress*, 2013.
- [37] Devlet Su İşleri. (2017, 4 Ekim). [Online]. Erişim: <http://rasatlar.dsi.gov.tr/>.
- [38] Cografyaharita.com (2017, 4 Ekim). [Online]. Erişim: <http://cografyaharita.com/haritalarim/2eturkiye-akarsu-havzolari-haritasi.png>
- [39] [tarimorman.gov.tr](https://www.tarimorman.gov.tr), Büyük Menderes Nehir Havzası Yönetim Planı (2021, 12 Haziran). [Online].Erişim:<https://www.tarimorman.gov.tr/SYGM/Belgeler/NHYP%20DEN%C4%B0Z/B%C3%9CY%C3%9CK%20MENDERES%20NEH%C4%B0R%20HAVZASI%20Y%C3%96NET%C4%B0M%20PLANI.pdf>